

# Predição de parâmetros advocatícios: uma abordagem utilizando modelos de aprendizado de máquina

Ana Carolina Figueiredo<sup>1</sup>, Helen C. de Mattos Senefonte<sup>1</sup>, Eliandro Cirilo<sup>2</sup>

<sup>1</sup>Departamento de Computação – Universidade Estadual de Londrina (UEL)  
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

<sup>2</sup>Departamento de Matemática – Universidade Estadual de Londrina (UEL)  
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

ana.carolina.figueiredo@uel.br, helen@uel.br, ercirilo@uel.br

**Abstract.** *With advancements in science and technology, artificial intelligence is increasingly being utilized. This work investigates the application of machine learning models in pricing services and negotiation strategies in law firms, identifying the parameters that most influence the successful negotiation of service.*

**Resumo.** *Com os avanços na ciência e na tecnologia, a inteligência artificial é cada vez mais utilizada. Este trabalho investiga a aplicação de modelos de aprendizado de máquina na precificação de serviços e estratégias de negociação em escritórios de advocacia, identificando os parâmetros que mais influenciam a concretização de contratos.*

## 1. Introdução

A precificação dos serviços jurídicos é uma dificuldade enfrentada por muitos advogados, uma série de fatores podem interferir no valor final, seja a complexidade dos casos, custo do escritório, taxas de juros, licenciamento profissional, entre outros. Tradicionalmente, o cálculo do valor dos serviços jurídicos dependia de métodos subjetivos, o que em alguns casos resultava em variações significativas [6].

No entanto, o progresso científico e tecnológico tem possibilitado avanços no campo da inteligência artificial (IA) e no aprendizado de máquina (ML). Essas tecnologias conseguem simular a resolução de problemas e a inteligência humana. Desta forma, IA vem ganhando espaço no setor jurídico, mostrando ser promissora na otimização de processos internos, na contribuição para a tomada de decisões, previsões sobre o desfecho de litígios e negociações [14].

Em um contexto em que a precisão e a eficiência são cruciais, a IA pode oferecer soluções inovadoras, alterando o modo de prestação e precificação dos serviços jurídicos. Ao permitir uma análise em grande escala e precisa, a IA tem a capacidade de revisar documentos, encontrar padrões nos contratos e, portanto, ajudar o sistema judiciário na automação [14]. Assim, IA está reinventando a profissão jurídica [15]. Motivado por esse fato, este trabalho propõe-se a investigar modelos de aprendizado de máquina capazes de serem aplicados na análise de dados, com o objetivo de identificar quais parâmetros dos escritórios de advocacia são mais relevantes para a concretização de contratos, buscando compreender quais fatores têm maior impacto, fornecendo insights para a otimização de estratégias de negociação e captação de clientes.

Este documento está organizado da seguinte maneira: a seção 2 apresenta os conceitos, métodos, técnicas e revisão do estado da arte necessários para a elaboração do sistema proposto. Na seção 3 é apresentado o objetivo a ser alcançando e o desenvolvimento, a seção 4 descreve como os objetivos serão atingidos fazendo uso da fundamentação teórico-metodológica e a revisão do estado da arte. Por fim, seção 5 mostra o cronograma de execução das atividades citadas na seção anterior e a seção 6 serão descritas as contribuições do trabalho no avanço e consolidação dos conhecimentos dos leitores.

## **2. Fundamentação Teórico-Metodológica e Estado da Arte**

### **2.1. Precificação usando Aprendizagem de Máquina**

A aplicação da aprendizagem de máquina na precificação de serviços tem se destacado por sua capacidade de otimizar preços de forma eficiente e adaptativa, pesquisas demonstram o potencial da aprendizagem de máquina para transformar a precificação de serviços.

O artigo "Learning-based dynamic ticket pricing for passenger railway service providers"[16] desenvolve o conceito de algoritmos de reforço para otimizar dinamicamente a precificação de bilhetes ferroviários com base na demanda prevista, otimizando a receita e equilibrando a ocupação de trens. Da mesma forma, no estudo "Pricing Prediction Services for Profit Maximization with Incomplete Information,"[8] os preços ótimos são previstos usando-se algoritmos de aprendizagem supervisionada - regressão linear e árvores de decisão - em um ambiente de informações incompletas. A imputação de dados é usada para preencher informações incompletas.

No mesmo contexto, pesquisas como "Optimal Pricing of Internet of Things: A Machine Learning Approach"[1], que utilizam métodos de agrupamento e regressão para segmentar o mercado e definir preços ótimos para produtos e serviços de IoT com base nas características dos clientes, e "Applying Machine Learning in Cloud Service Price Prediction: The Case of Amazon IaaS", [3] que emprega técnicas de modelagem como Redes Neurais e Máquinas de Vetores de Suporte (SVM) para prever com maior precisão os preços dos serviços de nuvem com base em dados históricos, demonstram o potencial da aprendizagem de máquina para transformar a precificação de serviços. Essas técnicas permitem estimar preços de forma mais precisa, evidenciando a capacidade do aprendizado de máquina em adaptar-se a variáveis dinâmicas e complexas.

### **2.2. Aprendizagem de Máquina**

O aprendizado de máquina (ML) é um conjunto específico de técnicas dentro da IA que se concentra em identificar padrões em dados por meio de algoritmos e funções matemáticas [11], podendo ser classificado em três categorias, cada uma com aplicações específicas relacionadas ao conjunto de dados de treinamento [7] : supervisionado, não supervisionado, e por reforço.

O **aprendizado supervisionado** utiliza dados rotulados podendo ser classificada em duas categorias de algoritmos a classificação e regressão. Esses dados são compostos por pares de entrada e saída. O objetivo do modelo é aprender a converter entradas em saídas corretas. Para isso, o treinamento é feito com um conjunto de dados e, depois, testado com outro conjunto para verificar sua precisão. Modelos treinados dessa forma detectam padrões nos dados na fase de calibração e utilizam esses padrões para realizar previsões ou classificações sobre novos dados de entrada [5].

Por outro lado, o **aprendizado não supervisionada** não recebe rótulos pré-definidos, ele utiliza técnicas de aprendizagem para identificar padrões. O modelo pode agrupar dados semelhantes em clusters, reduz a dimensionalidade para simplificação e detecta anomalias. Exemplo disso, seria usar essa técnica para reconhecer características semelhantes entre objetos diferentes e, em seguida agrupá-los em categorias [4].

Por fim, a **aprendizagem por reforço** (Reinforcent Learning -RL) é uma técnica em que o algoritmo aprende e reúne o conhecimento através da interação com o ambiente para tomar as ações adequadas. O funcionamento do modelo de RL pode ser exemplificado como um ciclo contínuo: o modelo observa o estado atual do ambiente, decide a melhor ação a ser tomada, executa a ação, e em seguida recebe um feedback na forma de recompensa. Esse processo se repete continuamente, permitindo que o algoritmo aprenda quais ações são mais vantajosas em diferentes situações[12].

### 2.2.1. Árvore de Decisão

As árvores de decisão são uma técnica de modelagem preditiva que ajuda a mapear diferentes decisões e suas consequências através de uma estrutura de ramificações. Elas são amplamente aplicadas em negócios, economia e gerenciamento de operações para analisar decisões organizacionais [10]. Uma árvore de decisão é composta por vários nós. O nó raiz é o ponto inicial da árvore, normalmente representam a base de dados, enquanto os nós internos correspondem aos atributos ou conjuntos deles. Os nós folha identificam o resultado final de uma série de decisões [2]. A Figura 1 mostra o esquema de uma árvore de decisão.

As árvores de decisão são uma abordagem de aprendizado de máquina supervisionado. Essa abordagem é geralmente utilizada na solução de problemas de classificação, fazendo uso de um modelo para categorizar ou classificar um objeto. As árvores de decisão são também utilizados em problemas de regressão, a qual faz análise preditiva para prever saídas de dados ainda não observados [10].

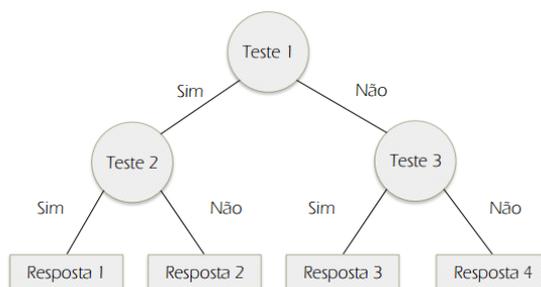


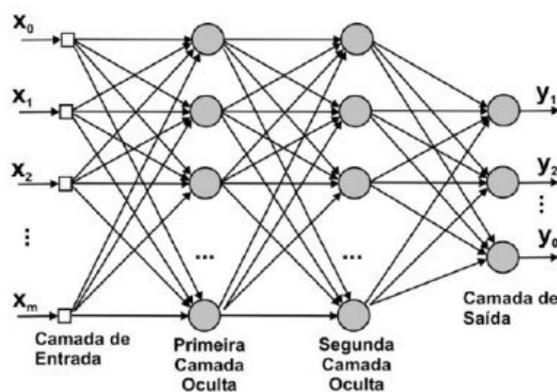
Figura 1. Árvore de Decisão

### 2.2.2. Rede Neural

Rede Neural(NN) é um algoritmo aplicado em vários campos do aprendizado de máquina. Inspirado no cérebro humano, o algoritmo utiliza unidades de processamento

de informação denominados neurônios para realizar cálculos complexos, esses neurônios por meio de conexões formam camadas sequencias [9]. Desta forma, as redes neurais artificiais estabelecem uma estrutura contendo uma camada de entrada, que recebe os dados iniciais, uma ou mais camadas escondidas e uma camada de saída como mostrado na Figura 2.

Uma rede neural pode ser treinada para executar uma tarefa específica ajustando os valores das conexões (pesos) entre os atributos, sendo importante para resolver problemas os quais são considerados difíceis para computadores convencionais ou seres humanos [13]. Redes Neurais podem classificadas conforme o tipo de tarefa a ser realizado. Redes Neurais Convolucionais (CNN) são utilizadas perincipalmente para manipulação de imagens, do mesmo modo que as Redes Neurais Recorrentes(RNN) é aplicada no processamento de dados sequenciais, como texto e séries temporais e Rendes Neurais de Longo e Curto Prazo (LTM) é projetada para aprender conexões em sequências de informação são usadas em tarefas como tradução automática e reconhecimento de fala.



**Figura 2. Rede Neural Artificial**

### 3. Objetivos

Este trabalho tem como objetivo principal construir um modelo computacional capaz de identificar quais parâmetros dos escritórios de advocacia são mais relevantes para a concretização de contratos. Buscando compreender quais fatores têm maior impacto na decisão de fechamento de contratos, gerando informações para estratégias de negociação e captação de clientes.

### 4. Procedimentos metodológicos/Métodos e técnicas

O desenvolvimento do projeto ocorrerá em sete fases: inicialmente uma revisão bibliográfica será feita, na sequência, as estratégias específicas para a implementação dos modelos irão ser definidas. A terceira fase será a coleta de dados. Na quarta parte os treinamentos dos modelos de aprendizado de máquina serão implementados, este processo incluirá a divisão dos dados em conjuntos de treinamento e teste, bem como o ajuste de hiperparâmetros para otimizar o desempenho dos modelos. A quinta fase será a análise dos resultados obtidos, comparando o desempenho dos diferentes algoritmos e identificando os fatores mais influentes na concretização de contratos. Esses resultados serão fundamentais para validar nossas hipóteses e refinar nossas estratégias. Em paralelo ocorrerão a preparação para a submissão de um artigo científico e escrita do TCC.

## 5. Cronograma de Execução

Atividades:

1. Revisão Bibliográfico;
2. Definição das estratégias;
3. Levantamento dos dados;
4. Testes, comparação e ajuste dos modelos;
5. Análise dos resultados;
6. Escrita da versão Preliminar do TCC;
7. Escrita da versão final do TCC ;

**Tabela 1. Cronograma de Execução**

	ago	set	out	nov	dez	jan	fev
Atividade 1	X	X	X	X			
Atividade 2	X	X					
Atividade 3	X	X	X	X			
Atividade 4		X	X	X	X	X	
Atividade 5			X	X	X	X	X
Atividade 6	X	X	X				
Atividade 7			X	X	X	X	X

## 6. Contribuições e/ou Resultados esperados

Este estudo busca aprofundar o conhecimento sobre o uso de modelos de aprendizado de máquina aplicados ao setor jurídico, especialmente para precificação de serviços e estratégias de negociação. Espera-se que a pesquisa identifique os principais fatores que influenciam a concretização de contratos. Os resultados poderão motivar a tomada de decisões estratégicas em escritórios de advocacia.

## 7. Espaço para assinaturas

Londrina, 29 de julho de 2024.

Ana Carolina Figueiredo

Aluno

Helen C. Mattos Senefonte

Orientador

## Referências

- [1] Mohammad Abu Alsheikh, Dinh Thai Hoang, Dusit Niyato, Derek Leong, Ping Wang, and Zhu Han. Optimal pricing of internet of things: A machine learning approach. *IEEE Journal on Selected Areas in Communications*, 38(4):669–684, 2020.
- [2] Songlin Bai. Application of computer science and technology intelligence based on improved decision tree algorithm. In *2023 3rd International Conference on Mobile Networks and Wireless Communications (ICMNWC)*, pages 1–5, 2023.

- [3] B Dhayanandan and R Rajeev. Cloud service price prediction using machine learning algorithm with api in the case of amazon web services and microsoft azure. In *2024 International Conference on Intelligent Systems for Cybersecurity (ISCS)*, pages 01–06, 2024.
- [4] Amit Jain and Shruti Rani. Machine learning and its applications: A study. In *2022 11th International Conference on System Modeling Advancement in Research Trends (SMART)*, pages 1503–1507, 2022.
- [5] Manish Kumar, Shueb Ali Khan, Abhay Bhatia, Vibhor Sharma, and Parag Jain. Machine learning algorithms: A conceptual review. In *2023 1st International Conference on Intelligent Computing and Research Trends (ICRT)*, pages 1–7, 2023.
- [6] Vikram Maheshri and Clifford Winston. An exploratory study of the pricing of legal services. *International Review of Law and Economics*, 38:169–173, 2014. Unlocking the Law: Building on the Work of Professor Larry E. Ribstein.
- [7] Michael G. Pecht and Myeongsu Kang. *Machine Learning: Fundamentals*, pages 85–109. 2019.
- [8] Huanhuan Peng, Xiaoye Miao, Lu Chen, Yunjun Gao, and Jianwei Yin. Pricing prediction services for profit maximization with incomplete information. In *2023 IEEE 39th International Conference on Data Engineering (ICDE)*, pages 1353–1365, 2023.
- [9] Alberto Prieto, Beatriz Prieto, Eva Martinez Ortigosa, Eduardo Ros, Francisco Pelayo, Julio Ortega, and Ignacio Rojas. Neural networks: An overview of early research, current frameworks and new challenges. *Neurocomputing*, 214:242–268, 2016.
- [10] Intan Rahmatillah, Eriana Astuty, and Ivan Diryana Sudirman. An improved decision tree model for forecasting consumer decision in a medium groceries store. In *2023 IEEE 17th International Conference on Industrial and Information Systems (ICIIS)*, pages 245–250, 2023.
- [11] Puru Rattan, Daniel D. Penrice, and Douglas A. Simonetto. Artificial intelligence and machine learning: What you always wanted to know but were afraid to ask. *Gastro Hep Advances*, 1(1):70–78, 2022.
- [12] Archana R Raut and S. P. Khandait. Machine learning algorithms in wsns and its applications. In *2021 International Conference on Computational Intelligence and Computing Applications (ICCICA)*, pages 1–5, 2021.
- [13] M. M Sahay, Kishan Bhushan e Tripathi. Uma análise da previsão de preços de curto prazo do mercado de energia usando ann. In *2014 6ª Conferência Internacional IEEE Power India (PIICON)*, 2014.
- [14] Riya Sil, Abhishek Roy, Bharat Bhushan, and A.K. Mazumdar. Artificial intelligence and machine learning based legal application: The state-of-the-art and future research trends. In *2019 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, pages 57–62, 2019.
- [15] Lalit Singh, Kavita Ajay Joshi, Ravindra Singh Koranga, Satish Chandra Pant, and Priya Mathur. Artificial intelligence in the legal profession: A review on its transformative potential and ethical challenges. In *Proceedings of the 5th International Conference*

*on Information Management & Machine Intelligence*, ICIMMI '23, New York, NY, USA, 2024. Association for Computing Machinery.

- [16] Ying-ting Zhu, Fu-zhang Wang, Xiao-yan Lv, and Yue Pan. Dynamic pricing for railway tickets with demand-shifted passenger groups. In *2014 International Conference on Management Science Engineering 21th Annual Conference Proceedings*, pages 256–262, 2014.